



Universidad Mariano Gálvez  
Ingeniería Electrónica  
Estadística inferencial

# Conceptos básicos

**Presenta**

**Dra. En Ing. Rita Victoria de León Ardón**

# Objetivo de la presentación

- Desarrollar el concepto de regresión múltiple y sus aplicaciones.
- Introducir los principios básicos de series de tiempos y aplicaciones

# Compromisos previos del estudiante

- Repasar las operaciones con matrices
- Recordar la solución de sistemas de ecuaciones
- Asistencia a clase 80%



# Repaso general (matrices)

Para los vectores  $\mathbf{y}_1 = \begin{bmatrix} 1 \\ 1 \\ 1 \end{bmatrix}$  and  $\mathbf{y}_2 = \begin{bmatrix} 2 \\ 0 \\ -1 \end{bmatrix}$

Encontrar

(a)  $2\mathbf{y}_1 + 3\mathbf{y}_2$

(b)  $\alpha\mathbf{y}_1 + \beta\mathbf{y}_2$

(c)  $\mathbf{y}_3$  Dado que  $3\mathbf{y}_1 - 2\mathbf{y}_2 + 4\mathbf{y}_3 = \mathbf{0}$

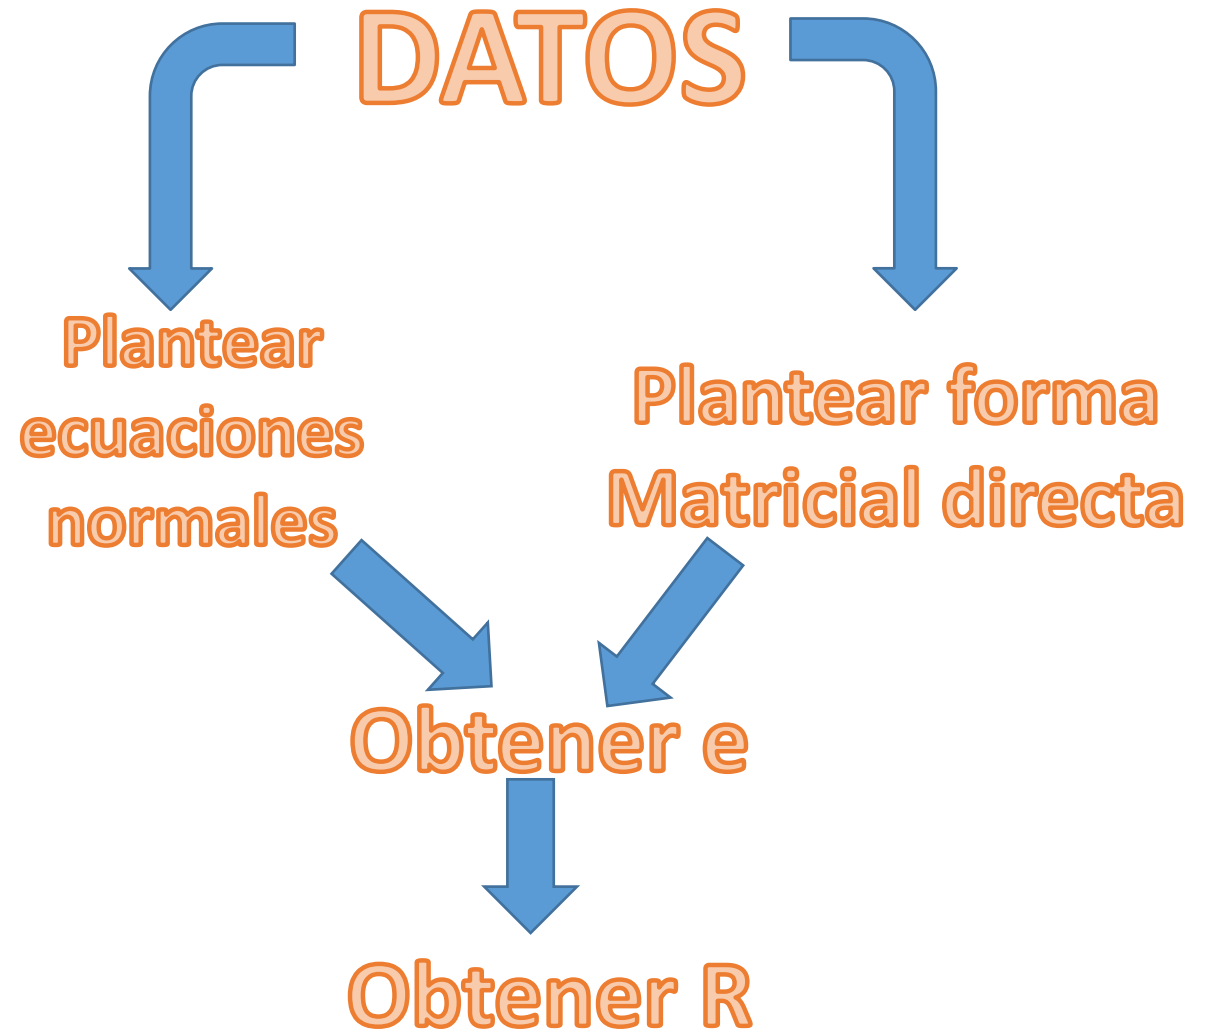
## Regresión lineal simple

Se estudia la relación entre dos variables

## Regresión lineal múltiple

Se estudia la relación entre tres o más variables

Modelos de  
regresión



# Regresión lineal simple

$$Y = \beta_0 + \beta_1 x + \epsilon$$

$$\left. \begin{aligned} n\hat{\beta}_0 + \hat{\beta}_1 \sum_{i=1}^n x_i &= \sum_{i=1}^n y_i \\ \hat{\beta}_0 \sum_{i=1}^n x_i + \hat{\beta}_1 \sum_{i=1}^n x_i^2 &= \sum_{i=1}^n y_i x_i \end{aligned} \right\}$$

Ecuaciones  
normales

Formas  
adicionales  
de cálculo

$$\hat{\beta}_1 = \frac{\sum_{i=1}^n y_i x_i - \frac{\left(\sum_{i=1}^n y_i\right)\left(\sum_{i=1}^n x_i\right)}{n}}{\sum_{i=1}^n x_i^2 - \frac{\left(\sum_{i=1}^n x_i\right)^2}{n}}$$


S<sub>xy</sub>

S<sub>xx</sub>

$$S_{xy} = \sum_{i=1}^n y_i (x_i - \bar{x})^2$$

$$S_{xx} = \sum_{i=1}^n (x_i - \bar{x})^2$$

# Regresión lineal simple





# Resolver

$$n = 20 \quad \sum_{i=1}^{20} x_i = 23.92 \quad \sum_{i=1}^{20} y_i = 1,843.21 \quad \bar{x} = 1.1960 \quad \bar{y} = 92.1605$$

$$\sum_{i=1}^{20} y_i^2 = 170,044.5321 \quad \sum_{i=1}^{20} x_i^2 = 29.2892 \quad \sum_{i=1}^{20} x_i y_i = 2,214.6566$$



# Resolver

X horas	Y puntaje	XY	X <sup>2</sup>
4	40	160	16
6	60	360	36
7	50	350	49
10	70	700	100
13	90	1170	169
40	310	2740	370

# Regresión lineal bivariante

$$Y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \epsilon$$

Y



$$\begin{aligned} n\hat{\beta}_0 + \hat{\beta}_1 \sum_{i=1}^n x_{i1} + \hat{\beta}_2 \sum_{i=1}^n x_{i2} &= \sum_{i=1}^n y_i \\ \hat{\beta}_0 \sum_{i=1}^n x_{i1} + \hat{\beta}_1 \sum_{i=1}^n x_{i1}^2 + \hat{\beta}_2 \sum_{i=1}^n x_{i1}x_{i2} &= \sum_{i=1}^n x_{i1}y_i \\ \hat{\beta}_0 \sum_{i=1}^n x_{i2} + \hat{\beta}_1 \sum_{i=1}^n x_{i1}x_{i2} + \hat{\beta}_2 \sum_{i=1}^n x_{i2}^2 &= \sum_{i=1}^n x_{i2}y_i \end{aligned}$$

Ecuaciones  
normales

# Regresión lineal múltiple

## modelo general

$$Y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \cdots + \beta_k x_k + \epsilon$$

$$n\hat{\beta}_0 + \hat{\beta}_1 \sum_{i=1}^n x_{i1} + \hat{\beta}_2 \sum_{i=1}^n x_{i2} + \cdots + \hat{\beta}_k \sum_{i=1}^n x_{ik} = \sum_{i=1}^n y_i$$

$$\hat{\beta}_0 \sum_{i=1}^n x_{i1} + \hat{\beta}_1 \sum_{i=1}^n x_{i1}^2 + \hat{\beta}_2 \sum_{i=1}^n x_{i1} x_{i2} + \cdots + \hat{\beta}_k \sum_{i=1}^n x_{i1} x_{ik} = \sum_{i=1}^n x_{i1} y_i$$

$\vdots$                      $\vdots$                      $\vdots$                      $\vdots$                      $\vdots$

$$\hat{\beta}_0 \sum_{i=1}^n x_{ik} + \hat{\beta}_1 \sum_{i=1}^n x_{ik} x_{i1} + \hat{\beta}_2 \sum_{i=1}^n x_{ik} x_{i2} + \cdots + \hat{\beta}_k \sum_{i=1}^n x_{ik}^2 = \sum_{i=1}^n x_{ik} y_i$$

Ecuaciones  
normales

# Modelos complejos de regresión múltiple

$$Y = \beta_0 + \beta_1x + \beta_2x^2 + \beta_3x^3 + \epsilon$$


**Polinomial**

$$Y = \beta_0 + \beta_1x_1 + \beta_2x_2 + \beta_{12}x_1x_2 + \epsilon$$

**Modelos de  
producto cruzados**

# Regresión lineal múltiple modelo general

$$Y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k + \epsilon$$



# Procedimiento 1

## 1. Plantear las ecuaciones normales

$$\begin{aligned} n\hat{\beta}_0 + \hat{\beta}_1 \sum_{i=1}^n x_{i1} + \hat{\beta}_2 \sum_{i=1}^n x_{i2} + \dots + \hat{\beta}_k \sum_{i=1}^n x_{ik} &= \sum_{i=1}^n y_i \\ \hat{\beta}_0 \sum_{i=1}^n x_{i1} + \hat{\beta}_1 \sum_{i=1}^n x_{i1}^2 + \hat{\beta}_2 \sum_{i=1}^n x_{i1}x_{i2} + \dots + \hat{\beta}_k \sum_{i=1}^n x_{i1}x_{ik} &= \sum_{i=1}^n x_{i1}y_i \\ \vdots & \\ \hat{\beta}_0 \sum_{i=1}^n x_{ik} + \hat{\beta}_1 \sum_{i=1}^n x_{ik}x_{i1} + \hat{\beta}_2 \sum_{i=1}^n x_{ik}x_{i2} + \dots + \hat{\beta}_k \sum_{i=1}^n x_{ik}^2 &= \sum_{i=1}^n x_{ik}y_i \end{aligned}$$

## 2. Resolver sistema de ecuaciones

## 3. Obtener ecuación de regresión

$$Y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k + \epsilon$$

## 4. Obtener e

## 5. Obtener R

# Procedimiento 2

## 1. Plantear la forma matricial

$$y = \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{bmatrix} \quad X = \begin{bmatrix} 1 & x_{11} & x_{12} & \dots & x_{1k} \\ 1 & x_{21} & x_{22} & \dots & x_{2k} \\ \vdots & \vdots & \vdots & \dots & \vdots \\ 1 & x_{n1} & x_{n2} & \dots & x_{nk} \end{bmatrix} \quad \beta = \begin{bmatrix} \beta_0 \\ \beta_1 \\ \vdots \\ \beta_k \end{bmatrix} \quad \text{and} \quad \epsilon = \begin{bmatrix} \epsilon_1 \\ \epsilon_2 \\ \vdots \\ \epsilon_n \end{bmatrix}$$

## 2. Resolver sistema de ecuaciones

$$\hat{\beta} = (X'X)^{-1} X'y$$

## 3. Obtener ecuación de regresión

$$Y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k + \epsilon$$

## 4. Obtener e

## 5. Obtener R

$$\hat{\sigma}^2 = \frac{\sum_{i=1}^n e_i^2}{n - p} = \frac{SS_E}{n - p}$$

p: número de parámetros

e: error total

n: número de  
observaciones totales

$$SCE = \sum_{i=1}^n e_i^2 = \sum_{i=1}^n (y_i - \hat{y}_i)^2.$$

$$STCC = \sum_{i=1}^n (y_i - \bar{y})^2 = \text{suma de cuadrados total}$$

$$SCR = \sum_{i=1}^n (\hat{y}_i - \bar{y})^2 = \text{suma de cuadrados de regresión}$$

$$STCC = SCR + SCE,$$



## Coeficiente de correlación múltiple

$$R^2 = \frac{SCR}{STCC} = \frac{\sum_{i=1}^n (\hat{y}_i - \bar{y})^2}{\sum_{i=1}^n (y_i - \bar{y})^2} = 1 - \frac{SCE}{STCC}.$$

## Coeficiente ajustado de correlación múltiple

$$R_{\text{ajus}}^2 = 1 - \frac{SCE / (n - k - 1)}{STCC / (n - 1)}.$$

---

# Plantear ecuaciones normales

Muestra	Y	X <sub>1</sub>	X <sub>2</sub>	Muestra	Y	X <sub>1</sub>	X <sub>2</sub>
1	9.95	2	50	14	11.66	2	360
2	24.45	8	110	15	21.65	4	205
3	31.75	11	120	16	17.89	4	400
4	35.00	10	550	17	69.00	20	600
5	25.02	8	295	18	10.30	1	585
6	16.86	4	200	19	34.93	10	540
7	14.38	2	375	20	46.59	15	250
8	9.60	2	52	21	44.88	15	290
9	24.35	9	100	22	54.12	16	510
10	27.50	8	300	23	56.63	17	590
11	17.08	4	412	24	22.13	6	100
12	37.00	11	400	25	21.15	5	400
13	41.95	12	500				

# Plantear ecuaciones normales

$y$	$x_1$	$x_2$
293	1.6	851
230	15.5	816
172	22.0	1058
91	43.0	1201
113	33.0	1357
125	40.0	1115

# Series de tiempo



# Series de tiempo

- Datos puntuales medidos en intervalos de tiempo uniformes y sucesivos.
- Se asume **Estacionariedad** es decir que los valores pasados y futuros son estadísticamente similares.
- Un concepto importante es el **de números índice**: son los que expresan un cambio promedio en las variables. Ejemplos:
  - el PIB se incremento en un **45%** respecto al 2016.
  - La tasa de cambio de dólares a quetzales bajó en un **37%** respecto al 2013.

# Obtener los números índices (I):

Año	valor	Número índice
1999	7.54	
2001	7.45	
2002	7.34	
2003	7.23	
2004	8.98	



$$I = \left( \frac{\text{Valor}_{\text{año muestra}} - \text{Valor}_{\text{año base}}}{\text{Valor}_{\text{año base}}} \right) * 100\%$$

# Datos no estacionarios

La mayoría de los métodos para el análisis de series de tiempo suponen estacionariedad en los datos. Sin embargo, muchos procesos no son estacionarios, exhiben ciclos: ej. ventas anuales, demanda mensual, lluvia, temperatura. Cuando trabajamos con datos no estacionarios, hay que:

- **1) Transformación matemática de los datos no-estacionarios para aproximar la estacionariedad: es decir, producir una serie que tenga media y varianza constantes.**
- **2) Dividir los datos para realizar análisis separados sobre subconjuntos que sean suficientemente cortos.**

# Modelos series de tiempo

$$Y_t = f(S_t, T_t, E_t)$$

$Y_t$ = son los valores actuales en un período  $t$

$S_t$ = es el componente estacional índice en el período  $t$

$T_t$ = es la tendencia en el período  $t$

$E_t$ = es el componente irregular en el período  $t$




Variación accidental: es el cambio que ocurre de forma imprevisible y ocasional



Tendencia: variación predominante en toda la serie

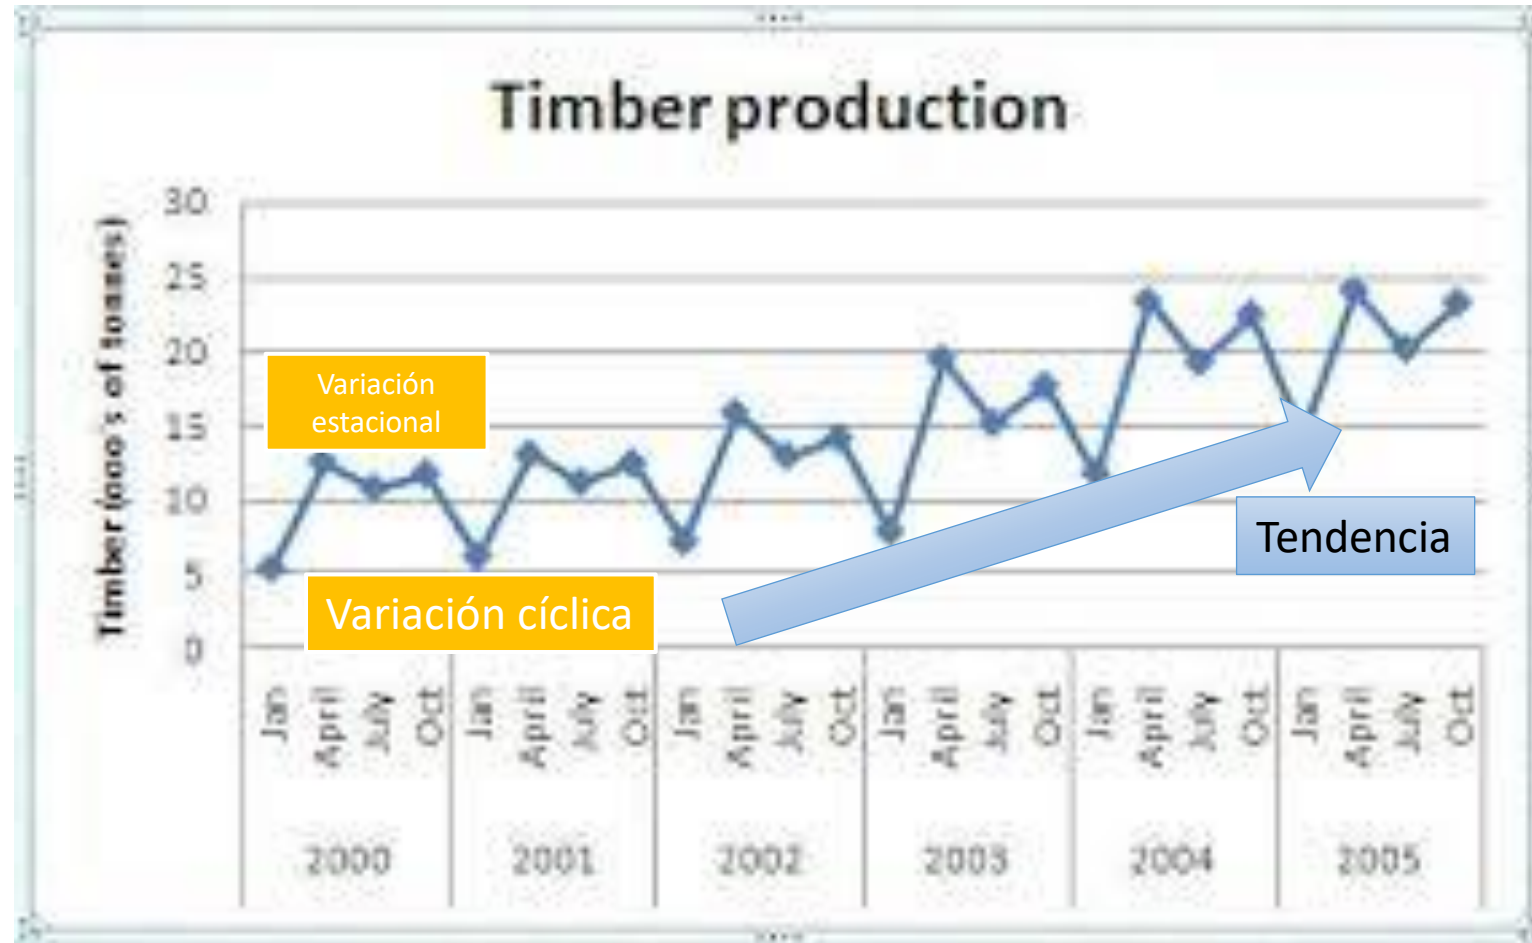
# Series de tiempo

Variación cíclica: es el cambio que ocurre en períodos mayores a un año.



Variación estacional: es el cambio entre períodos de la serie (ejemplo: verano, invierno, día-noche). Menor a un año.

# Identificar los tipos de variación y la tendencia




# Clases de tendencia

- Determinística: no cambia en el tiempo.
- Aleatoria: cambia con el tiempo.

# Series de tiempo

	Valores observados						Valores pronosticados			
<i>Período t</i>	$Y_1$	$Y_2$	$Y_3$	...	$Y_{n-1}$	$Y_n$				
	1	2	3	...	$n-1$	$n$	$n+1$	$n+2$	...	$n+m$
<i>Valores estimados</i>	$\hat{Y}_1$	$\hat{Y}_2$	$\hat{Y}_3$	...	$\hat{Y}_{n-1}$	$\hat{Y}_n$	$\hat{Y}_{n+1}$	$\hat{Y}_{n+2}$	...	$\hat{Y}_{n+m}$
	$F_1$	$F_2$	$F_3$	...	$F_{n-1}$	$F_n$	$F_{n+1}$	$F_{n+2}$	...	$F_{n+m}$
<i>Error</i>	$e_1$	$e_2$	$e_3$	...	$e_{n-1}$	$e_n$				

  
**Presente**

Client	Amount spent	Estimate of $\hat{Y} = 7$		Estimate of $\hat{Y} = 10$		Estimate of $\hat{Y} = 12$	
		Error <sup>a</sup>	Error squared	Error	Error squared	Error	Error squared
1	9	2	4	-1	1	-3	9
2	8	1	1	-2	4	-4	16
3	9	2	4	-1	1	-3	9
4	12	5	25	2	4	0	0
5	9	2	4	-1	1	-3	9
6	12	5	25	2	4	0	0
7	11	4	16	1	1	-1	1
8	7	0	0	-3	9	-5	25
9	13	6	36	3	9	1	1
10	9	2	4	-1	1	-3	9
11	11	4	16	1	1	-1	1
12	10	3	9	0	0	-2	4
SSE (sum of squared errors)			144		36		84
MSE (mean squared error)			12		3		7

periodo	observación	pronóstico	Error absoluto	Error Absoluto porcentual
$t$	$Y_t$		$ Y_t - F_t $	$\left  \frac{Y_t - F_t}{Y_t} \right  100$
1	138	182	44	31.9
2	136	138	2	1.5
3	152	136	16	10.5
4	127	152	25	19.7
5	151	127	24	15.9
6	130	151	21	16.2
7	119	130	11	9.2
8	153	119	34	22.2
Total			177	127.1

$$\text{MAE} = 177/8 = 22.1$$

$$\text{MAPE} = 127.1/8 = 15.9\%$$

Cálculos

# Modelos de autorregresión

- Definimos un modelo como autorregresivo si la variable endógena de un período  $t$  es explicada por las observaciones de ella misma correspondientes a períodos anteriores añadiéndose, como en los modelos estructurales, un término de error.
- Los modelos autorregresivos se abrevian con la palabra AR tras la que se indica el orden del modelo: AR(1), AR(2), ..., AR(P)

# Modelo autorregresivo de orden p -AR(p)-: expresión matemática

$$X_t = \phi_1 X_{t-1} + \phi_2 X_{t-2} + \dots + \phi_p X_{t-p} + w_t$$

*donde  $X_t$  es estacionario,  $\phi_1, \phi_2, \dots, \phi_p$  son constantes ( $\phi_p \neq 0$ ) y  $w_n$  es un ruido blanco con media 0 y varianza  $\sigma_w^2$ .*

El proceso  $X_t$  tiene media 0. Si queremos analizar un proceso  $Y_t$  con media  $\mu \neq 0$  podemos considerar el proceso  $Y_t - \mu$ .

$X_t$ =variable de respuesta en el tiempo t

$X_{t-p}$ = observación (variable predictiva) en el tiempo t-p

$\phi_p$ =coeficientes de regresión a estimar

$w_t$ = error en el tiempo t



# Función de autocorrelación ( $\rho_k$ ) o (ACF) o ( $r_k$ )

La correlación entre observaciones en P periodos de tiempo es:

$$\rho_P = \emptyset^P \quad r_k = \frac{\sum_{t=k+1}^n (Y_t - \bar{Y})(Y_{t-k} - \bar{Y})}{\sum_{t=1}^n (Y_t - \bar{Y})^2}$$


# AR(1)

- El valor de una serie mañana ( $X_t$ ) es el valor de hoy ( $X_{t-1}$ ) más un cambio impredecible ( $w$ ).


$$X_t = \phi X_{t-1} + w_t$$

Caminata aleatoria

AR(1)  $\phi=+0.9$




AR(1)  $\phi=-0.9$




$\rho_P$

Correlación AR(1)  $\phi=+0.9$




$\rho_P$

Correlación AR(1)  $\phi=-0.9$




$\phi$  está relacionado con el nivel de estabilidad


**ACF for AR(1),  $\phi=0.5$**







**ACF for AR(1),  $\phi=0.8$**



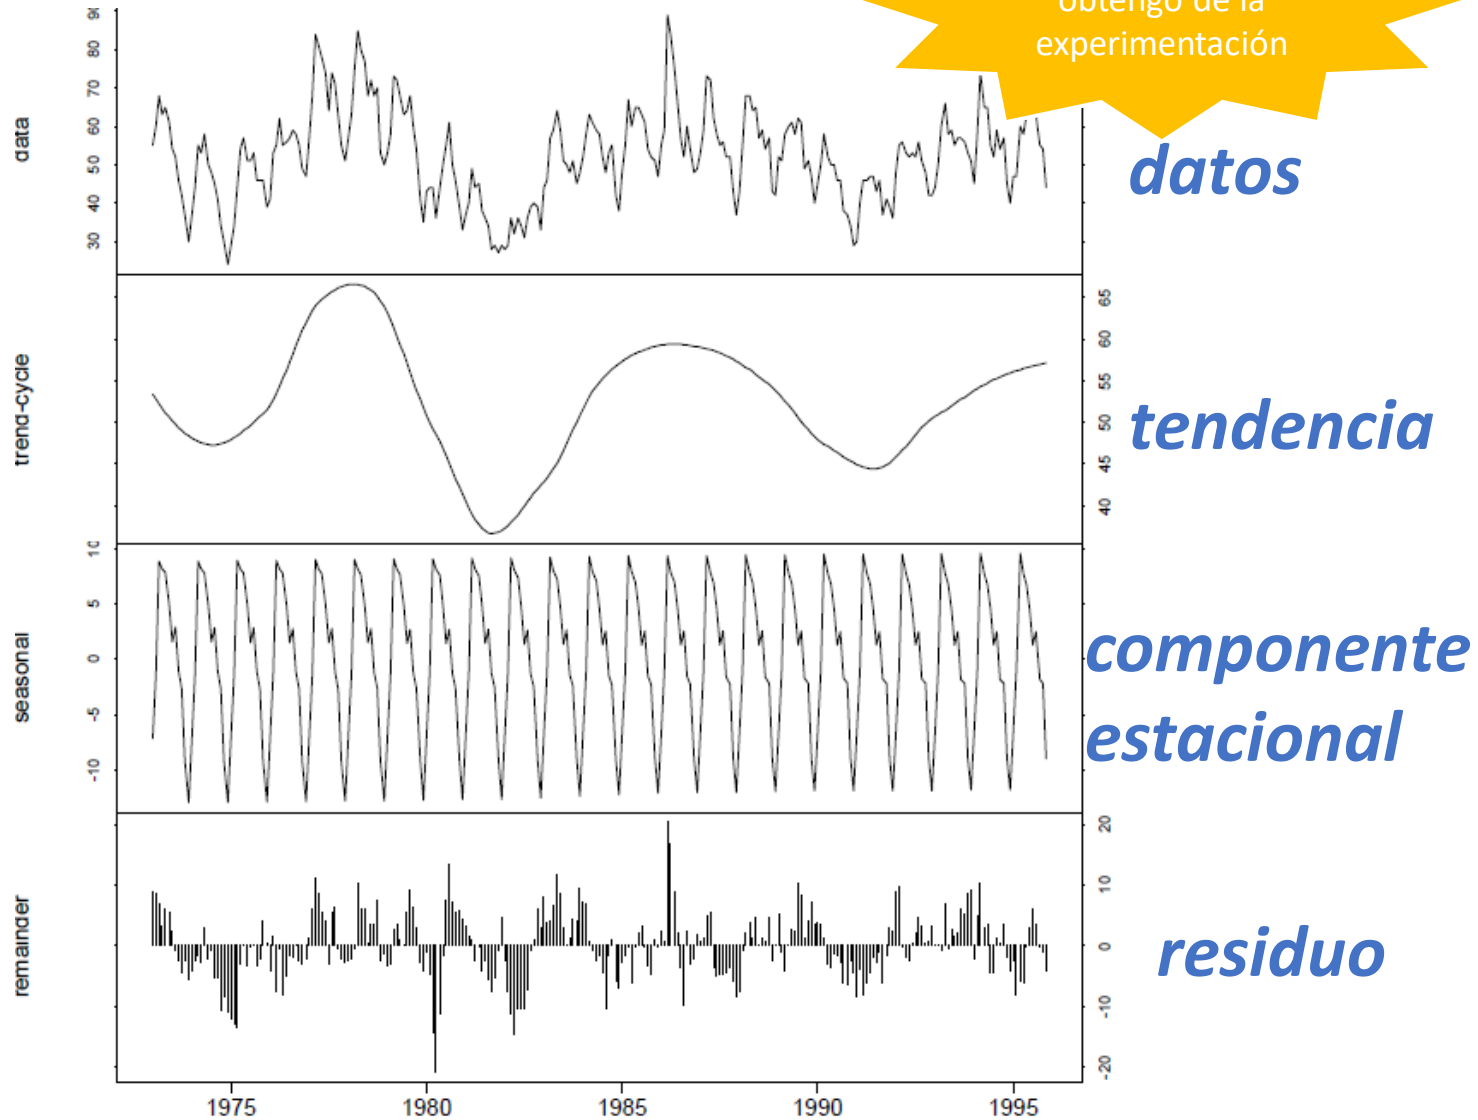
**ACF for AR(1),  $\phi=0.99$**



¿En cuál de estos gráficos  $\theta$  es negativo o positivo?



Esto es lo que  
obtengo de la  
experimentación



*datos*

*tendencia*

*componente  
estacional*

*residuo*

¿Qué hago para  
resolver el  
problema?



$$Y_t = S_t + T_t + E_t$$

$$Y_t = S_t \times T_t \times E_t.$$



$$\log Y_t = \log S_t + \log T_t + \log E_t.$$

1. Calcular los promedios móviles (componente tendencial)

$$T_t = \frac{1}{k} \sum_{j=-m}^m Y_{t+j}$$

2. Obtener los radios (componente estacional)

$$R_t = \frac{Y_t}{T_t} \quad S_{ti} = \frac{\sum_0^i R_t}{n}$$

3. Obtener componente irregular

Nota: hay muchos procedimientos, este sólo es uno de ellos. Lo importante es tener claro que hay un componente tendencial uno estacional y el irregular.



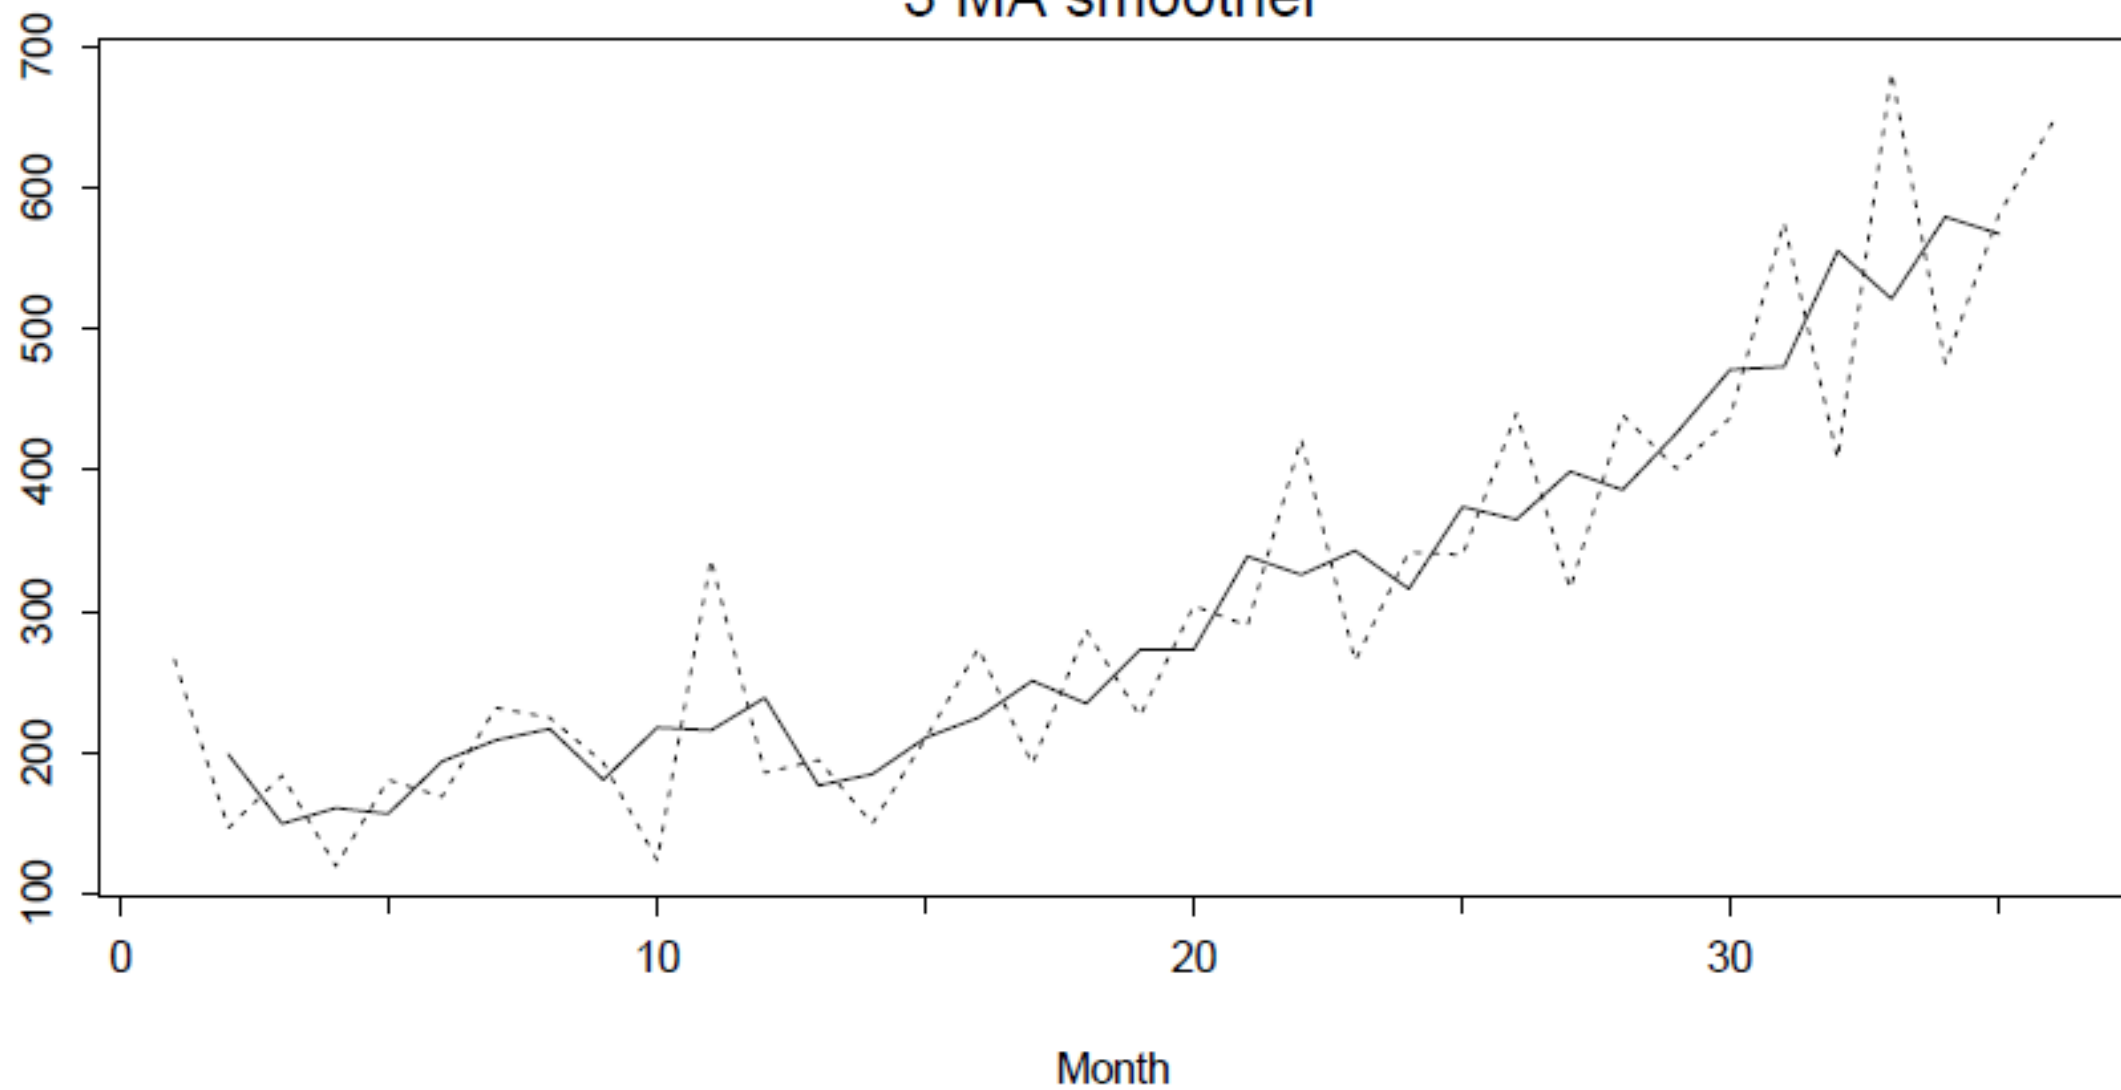
$$Y_t = S_t + T_t + E_t$$



Para calcularla usar:

- Promedios móviles
- Promedios móviles centrados
- Promedios móviles dobles
- Promedios con pesos

3 MA smoother



Promedios móviles simples pueden definirse para cualquier número impar. Un promedio móvil de orden  $k$ , donde  $k$  es un número impar está definido como el promedio que consiste en una observación y los  $m$  puntos a cada lado.

$$T_t = \frac{1}{k} \sum_{j=-m}^m Y_{t+j} \quad m = (k - 1)/2$$

$$T_t = \frac{1}{5} (Y_{t-2} + Y_{t-1} + Y_t + Y_{t+1} + Y_{t+2})$$

$K=$  en 5 meses, en dos meses, en tres meses...

Ejemplo: obtener el promedio móvil de la siguiente serie de datos, considerando un promedio móvil de 3.

## Componente tendencial

Mes		Datos reales	Datos estimados mediante promedio móvil	Datos estimados mediante promedio móvil dobles	Pesos	Promedio móvil con pesos
Enero	1	266	266	266	0.5	$=266*0.5=133$
Febrero	2	145.9	$=$ $\frac{1}{3}(266+145.9+183.1)=198.33$	$\frac{1}{3}(266+198.33+149.43)=204.59$	0.8	$=\frac{1}{3}(266*0.5+145.9*0.8+183.1*0.7)=125.94$
Marzo	3	183.1	$=$ $\frac{1}{3}(145.9+183.1+119.3)=149.43$	$\frac{1}{3}(198.33+149.43+160.9)=169.53$	0.7	$\frac{1}{3}(145.9*0.8+183.1*0.7+119.3*0.6)=105.49$
Abril	4	119.3	$=$ $\frac{1}{3}(183.1+119.3+180.3)=160.9$	$\frac{1}{3}(149.43+160.9+180.3)=163.54$	0.6	$\frac{1}{3}(183.1*0.7+119.3*0.6+180.3*0.5)=96.33$
Mayo	5	180.3	180.3	180.3	0.5	90.15

$$Y_t = S_t + T_t + E_t$$



Para calcularla usar:  
Primero el valor  
irregular estacional.  
Segundo calcular el  
índice estacional.  
Tercero: des-  
estacionalizar la serie

# Componente estacional

Mes		Datos reales (yt)	Datos estimados mediante promedio móvil (Tt)	Rt (valor irregular estacionario)
Enero	1	266	----	----
Febrero	2	145.9	198.33	$= (145.9/198.33) * 100 = 73.56$
Marzo	3	183.1	149.43	$= (183.1/149.43) * 100 = 122.53$
Abril	4	119.3	160.9	74.14
Mayo	5	180.3	-----	-----
				$= (73.56 + 122.53 + 74.14) / 3 = 90.076$

Año	Cuatrimestre	Ventas	Promedio móvil centrado	Índice r. Valor estacional irregular
1	1	4.8		
1	2	4.1		
1	3	6.0	5.475	1.096
1	4	6.5	5.738	1.133
2	1	5.8	5.975	0.971
2	2	5.2	6.188	0.840
2	3	6.8	6.325	1.075
2	4	7.4	6.400	1.156
3	1	6.0	6.538	0.918
3	2	5.6	6.675	0.839
3	3	7.5	6.763	1.109
3	4	7.8	6.838	1.141
4	1	6.3	6.938	0.908
4	2	5.9	7.075	0.834
4	3	8.0		
4	4	8.4		


Cuatrimestre	Índice r. Valor estacional irregular			Índice estacional (valores r promediados)
1	0.971	0.918	0.908	0.93
2	0.840	0.839	0.834	0.84
3	1.096	1.075	1.109	1.09
4	1.133	1.156	1.141	1.14



Año (1)	Cuatrimestral (2)	Observación (3)	Ventas (4)	Índice estacional - valores r promediados- (5)	Des-estacionalizadas (6)
1	1	1	4.8	0.93	5.16
	2	2	4.1	0.84	4.88
	3	3	6.0	1.09	5.50
	4	4	6.5	1.14	5.70
2	1	5	5.8	0.93	6.24
	2	6	5.2	0.84	6.19
	3	7	6.8	1.09	6.24
	4	8	7.4	1.14	6.49
3	1	9	6.0	0.93	6.45
	2	10	5.6	0.84	6.67
	3	11	7.5	1.09	6.88
	4	12	7.8	1.14	6.84
4	1	13	6.3	0.93	6.77
	2	14	5.9	0.84	7.02
	3	15	8.0	1.09	7.34
	4	16	8.4	1.14	7.37


$$5.16 = 4.8 / 0.93$$

Ahora es tiempo de pronosticar...



# Para pronosticar series de tiempo...

- Se puede utilizar la regresión lineal simple.
- Se puede utilizar el suavizamiento exponencial.
- Otros métodos (la ciencia no es estática evoluciona, cada día se crean mejores formas de resolver problemas). Por eso siempre hay que estar investigando y actualizándose.



Cuadrática

$$W_t = \sqrt{Y_t}$$

Cúbica

$$W_t = \sqrt[3]{Y_t}$$


Logarítmica

$$W_t = \log(Y_t)$$


Inversa negativa

$$W_t = -1/Y_t$$


Cube root of electricity production



Logarithm of electricity production



Negative reciprocal of electricity production



## Ejercicio:

- Para los datos dados en el ejemplo anterior, obtenga la regresión lineal simple correspondiente para los datos: a) reales; b) suavizados; c) y des-estacionalizados.
- Obtenga el pronóstico para la observación, 17, 18 y 19 en los tres casos y compare los errores.
- Realice un ajuste estacional para el pronóstico (es decir multiplique el resultado de la recta de regresión des-estacionalizada y multiplique por el índice correspondiente).

**OJO: una actividad similar probablemente examen.**

# Suavizamiento exponencial: otra forma de pronosticar..

$$\underbrace{F_{t+1}}_{\text{Pronóstico}} = \alpha Y_t + (1 - \alpha) \underbrace{F_t}_{\text{Pronóstico inmediato anterior}}$$

**Peso del suavizamiento. Entre 0 y 1.**

**Valor real**

Mes	Observación	Metros de tela producidos	Suavizamiento exponencial		
			$\alpha = 0.1$	$\alpha = 0.5$	$\alpha = 0.9$
Jan	1	200.0	—	—	—
Feb	2	135.0	200.0	200.0	200.0
Mar	3	195.0	193.5	167.5	141.5
Apr	4	197.5	193.7	181.3	189.7
May	5	310.0	194.0	189.4	196.7
Jun	6	175.0	205.6	249.7	298.7
Jul	7	155.0	202.6	212.3	187.4
Aug	8	130.0	197.8	183.7	158.2
Sep	9	220.0	191.0	156.8	132.8
Oct	10	277.5	193.9	188.4	211.3
Nov	11	235.0	202.3	233.0	270.9
Dec	12	—	205.6	234.0	238.6

Arrastramos el dato de enero como el pronóstico de febrero

$$F_{t+1} = \alpha Y_t + (1 - \alpha) F_t$$

$$F_{\text{feb}} = 0.1(135) + (0.9)(200) = 193.5$$

$$F_{\text{marzo}} = 0.1(195) + 0.9(193.5) = 193.65 \approx 193.7$$

# El método de pronóstico de Holt


$$L_t = \alpha d_t + (1 - \alpha)F_{t-1}$$

$$b_t = \beta(L_t - L_{t-1}) + (1 - \beta)b_{t-1}$$

$$F_{t+1} = L_t + b_t$$

$$L_1 = d_1, b_1 = d_2 - d_1$$

$$\alpha, \beta \in (0, 1)$$

$\alpha$   $\beta$   Coeficientes de suavizamiento exponencial

$L_t =$  *tendencia actual*

$b_t =$  *término independiente*

$L_{t-1} =$  *tendencia anterior*

$b_{t-1} =$  *término independiente anterior*

$F_{t+1} =$  *pronóstico*

$d_t =$  *dato real*



Period ( $t$ )	Observed data ( $Y_t$ )	Smoothing of data ( $L_t$ )	Smoothing of trend ( $b_t$ )	Forecast when $m = 1$ ( $F_t$ )
1	143	143.00	9.00	—
2	152	152.00	9.00	152.00
3	161	161.00	9.00	161.00
4	139	154.47	7.88	170.00
5	137	149.64	6.96	162.34
6	174	165.32	7.59	156.60
7	142	157.42	6.47	172.91
8	141	152.42	5.64	163.89
9	162	160.03	5.78	158.06

$$\alpha = 0.501 \text{ and } \beta = 0.072.$$



Compruebe usted estos pronósticos mediante Holt.

**Tabla 19.8.** Cálculos del crédito al consumo pendiente basados en el  $\pi$  de Holt-Winters ( $\alpha = 0,3$ ,  $\beta = 0,4$ ) y realizados a partir de la salida Min

$t$	$x_t$	$\hat{x}_t$	$T_t$
1	133		
2	155	155	22
3	165	169	17
4	171	175	11
5	194	192	14
6	231	223	25
7	274	266	36
8	312	309	40
9	313	324	25
10	333	338	18
11	343	347	13




Compruebe usted estos pronósticos mediante Holt.

Revisar el link:

<http://www.zaitunsoftware.com>

## Tarea

Comparar los resultados del software con los obtenidos en esta tabla.



Period	Sales	Estimated sales
$X_i$	$Y_i$	$\hat{Y}_i$
1	30	26.73
2	20	30.12
3	45	33.52
4	35	36.91
5	30	40.30
6	60	43.70
7	40	47.09
8	50	50.48
9	45	53.88
10	65	57.27

Fin  
unidad 1

